

本周工作报告

一、概述

由于本周有一门学校考试，论文只精度了两篇。其实真正本质的原因是低效地读论文效率。我觉得我读论文低效的原因有四：1、过于沉溺于所谓的长时间工作，即努力上面。实际上我在用时间上的努力，掩盖我思想上的偷懒2、不会有选着性地挑选重点来读3、没有带着研究目的去读4、老是带着敬畏去详读顶会论文，顶会论文也一样有错，浪费了不少时间。

为了验证我的假设是否正确，下周重点目标，把数量提上去。脚踏实地，基础差，就先从小事做起，从点点滴滴开始积累。同时完成课程和研究方向的任务

找嵩博讨论，拟写一篇文献综述

二、《Analyzing the Training Processes of Deep Generative Models》

背景：

1、Deep Generative Model(DGM 深度生成模型)的特性(需要技巧、经验以及知道此类模型会比其它类的优越在哪里)决定了网络的效果会受到开发人员对网络理解的影响

2、可视化 DGM 模型对神经网络的专家的理论 and 实际有十分重要的意义

贡献：


1、一个帮助更好理解神经网络的训练过程的可视分析工具，能够分析出导致神经网络训练出错的源头

2、运用蓝噪声采样算法(一种基于样本值的取值区间均匀采样的算法，有别于相对个体等概率采样的算法)优化折线图，在减少混杂的同时保留离群点

3、一个输出贡献度指派算法，用来衡量在训练过程中一个神经元的前驱和后继究竟起了多大作用。特别注意本文特意提出：神经元的后继对其输出也有贡献，比如有一个

方法：

1、如下图所示，采用如下方法降低混乱，对于全连接层，先对神经元进行聚类，每个聚类用一个小方格表示，同时对于每个聚类只显示类内的均值。同时对于全局只显示高贡献聚类



同时对于 CNN，用 feature map 代替全连接的神经元，对 feature map 聚类，则处理方法同全连接层。最后采用 Hover 方式交互，即一种 Focus+Context 的交互方法

2、使用 state-of-the-art 的前向传播贡献计算方法计算了前向传播的贡献

$$C(a_i^{l-1} \rightarrow a_j^l) = w_{ij} a_i^{l-1} / Z, \quad (1)$$

where $Z = \sum_h w_{hj} a_h^{l-1}$ is a normalization factor.


同时根据反向传播公式推导反向传播贡献

$$C(a_k^{l+1} \rightarrow a_j^l) = w_{kj} a_k^{l+1} / Y, \quad (3)$$

where $Y = \sum_h w_{jh} a_h^{l+1}$ is a normalization factor. The detailed deduction

贡献最终表示在可视化的 feature map 图中，正向贡献用红色，反向贡献用蓝色

3、采用蓝噪声采样算法，优化折线图结果。结果如下：



4、其它研究者使用该工具推断出了在 VAE 中使用 log 变量的不足

未来工作：

- 1、本文是离线结果分析，希望能发展成为在线结果分析
- 2、引入数据挖掘中的模式挖掘技术
- 3、分析训练过程所需要的数据量

借鉴：

- 1、之前做过 类似的深度学习工作，对可视化工具辅助理解深度学习有了更深刻的认识
- 2、之前有一篇 DQNVIS 的论文就将模式挖掘的方法引入 Vis 中，两篇呼应，又给了我新的感受


三、《What have we learned from deep representations for action recognition?》

背景：

- 1、2015 年第一篇基于 activation maximization 方法的可视化论文发表，这是第一篇应用在 ImageNet 上训练的神经网络的可视化方法
- 2、CNN 可视化方法分为两种：a、在给定图片中的可视化方法，从给定图片中找出最大激活的输入 b、激活最大化的方法(Activation Maximization)
- 3、生成对抗的结构和 Activation Maximization 实际上是一致的

方法：

- 1、一下网络结构仅仅是因为本文作者希望把它的可视化方法应用在视屏中，故选用时空数据中最常用的可视化结构。



- 2、核心在于红线处的 3 个方向，选定需要可视化的那一层作为 loss，把它当做 GAN 的输出层，用反向传播算法，但是不求导，把正向传播的激活作为权值，最优化一下目标，求出输入，即生成可视化结果，下图为优化目标

$$\mathbf{x}^* = \operatorname{argmax}_{\mathbf{x}} \frac{1}{\rho_l^2 \hat{\mathbf{a}}_{l,c}} \langle \mathbf{a}_l(\mathbf{x}), \mathbf{e}_c \rangle - \lambda_r \mathcal{R}_r(\mathbf{x}) \quad (1)$$

- 3、正则化项—惩罚项。下图为分别为图像正在化项、平滑正则化项，通过添加正则化项来约束生成的可视化结果的输入域，平滑时间域的可视化结果

$$\mathcal{R}_B(\mathbf{x}) = \begin{cases} N_B(\mathbf{x}) & \forall i, j, k : \sqrt{\sum_d \mathbf{x}(i, j, k, d)^2} \leq B \\ +\infty, & \text{otherwise.} \end{cases} \quad (2)$$

$$\mathcal{R}_{TV}(\mathbf{x}; \kappa, \chi) = \sum_{ijkd} [\kappa ((\nabla_x \mathbf{x})^2 + (\nabla_y \mathbf{x})^2) + \chi (\nabla_t \mathbf{x})^2], \quad (3)$$

优点：

- 1、本文首次提出了层次 CNN 可视化方法，可以根据需要获得不同层次的可视化结果
- 2、利用式(3)平滑因子得到了视屏流(时空数据)的可视化结果
- 3、该可视化方法一定程度上可以认知神经网络学到的东西，对神经网络原理的理解意义较大，但对实际应用该技术，解决神经网络的问题，还存在一定的困难

不足：

- 1、本文提出的论文理论意义大于实践意义，即为一些网络的有效性提出了一定的证明材料
- 2、对比刘世霞老师的论文可以发现，刘世霞老师提出的是一种可视分析系统，切实地解决了生成对抗网络的训练难问题，重在分析。而本文提出的是一种可视化系统，重在无目标的展现。从实践角度而言，刘的论文为后人的工作指明了方向

本周工作时间：

周一：看论文

周二-周五：课程设计

周六-周日：看论文

所有工作日均全勤，那我的问题，其实在于，我在用自己的努力，去掩饰自己的偷懒

